

## تحلیل قابلیت اعتماد سازه‌ها براساس روش ترکیبی کوچک‌ترین مربعات بردارهای پشتیبان و شبیه‌سازی مونت کارلوی پیشرفته\*

(یادداشت پژوهشی)

<sup>(۱)</sup> محمد مهدی مجاهد<sup>(۲)</sup> بهروز احمدی ندوشن

**چکیده** باتوجه به کوچک بودن احتمال خرابی سازه‌ها، تحلیل قابلیت اعتماد سازه‌ها هزینه زمانی بالایی را به همراه خواهد داشت. در این مقاله، به منظور کاهش زمان محاسبات، الگوریتمی براساس ترکیب روش رگرسیون کوچک‌ترین مربعات دستگاه بردارهای پشتیبان و دو روش شبیه‌سازی مونت کارلوی پیشرفته: نمونه‌برداری با اهمیت و ابرمکعب لاتینی، ارائه شده است. با ارائه دو مثال قاب و یک مثال خرپا کارایی الگوریتم‌های پیشنهادی مورد ارزیابی قرار گرفته است. نتایج حاصل نشان می‌دهد که روش پیشنهادی می‌تواند احتمال خرابی را به خوبی تخمین زند و زمان محاسبات در مقایسه با دیگر روش‌های ارائه شده در سال‌های اخیر بسیار کمتر می‌باشد.

**واژه‌های کلیدی** قابلیت اعتماد سازه‌ها، روش‌های پیشرفته شبیه‌سازی مونت کارلو، دستگاه بردارهای پشتیبان، احتمال خرابی.

## Least Squares Support Vector Machine-based Advance Monte Carlo Methods for Reliability Analysis of Structures

M. Mojahed

B. Ahmadi-Nedushan

**Abstract** The failure probability of structures are rather small and therefore calculation of structural reliability generally has a high computational cost. In order to reduce computational costs, this articles proposes a hybrid approach based on combination of the least squares support vector regression and two advanced Monte Carlo methods: importance sampling and Latin hypercube sampling. Two frames and one truss example are used to evaluate the performance of the proposed algorithm. Results demonstrate that proposed method provides an accurate estimation of failure probability and that the computational costs are lower than those of other methods.

**Key Words** Structural Reliability, Advanced Monte Carlo Methods, Support Vector Machine, Failure Probability.

---

\* تاریخ دریافت مقاله ۹۱/۱۲/۳ و تاریخ پذیرش آن ۹۲/۱۱/۹ می‌باشد.

(۱) نویسنده مسئول، دانشجوی کارشناسی ارشد سازه، دانشکده عمران، پردیس فنی و مهندسی، دانشگاه یزد.

Email: mahdimojahed@gmail.com

(۲) دانشیار دانشکده عمران، پردیس فنی و مهندسی، دانشگاه یزد.

### مقدمه

قابلیت اعتماد، موضوعی بااهمیت در تحلیل و طراحی سازه‌ها می‌باشد. بحث اصلی تحلیل قابلیت اعتماد سازه‌ها، محاسبه تخمین احتمال خرابی ناشی از عدم قطعیت پارامترها خواهد بود. به دلیل ماهیت غیرقطعی پارامترهای سازه و در دسترس نبودن تابع حالت حدی به فرم ریاضی، محاسبه ایمنی مطلق غیرممکن می‌باشد [1].

باتوجه به مشکلات روش‌های تحلیلی و شبیه‌سازی، از اوایل دهه ۸۰ میلادی روش‌های سطح پاسخ به‌منظور کاهش حجم محاسبات و در نتیجه کاهش هزینه زمانی ناشی از روش‌های المان محدود به‌کار گرفته شدند. ایده اساسی این روش‌ها، جایگزینی توابع حالت حدی با توابع سطح پاسخ ساده‌تر می‌باشد. با تخمین تابع عملکرد مناسب، می‌توان تحلیل قابلیت اعتماد سازه‌ها را به‌درستی انجام داد [2-4].

در دو دهه اخیر با پیشرفت تحقیقات در زمینه هوش مصنوعی، روش شبکه عصبی مصنوعی به‌منظور تقریب تابع عملکرد به‌سرعت جایگزین روش‌های پیشین شد. کاربرد و جوانب مختلف روش شبکه عصبی در بسیاری از مقالات مطرح شده است [5-7]. شبکه عصبی با تمام مزیت‌هایی که نسبت به روش‌های کلاسیک دارد، در بسیاری از مسائل سازه‌ای با تعداد متغیرهای زیاد می‌تواند هزینه زمانی نسبتاً زیادی، برای محاسبات دربر داشته باشد [8].

در همین راستا برای رفع مشکلات شبکه عصبی، روش رگرسیون دستگاه بردار پشتیبان (Support Vector Machine (SVM) به‌عنوان یک روش یادگیری هوشمند برای به‌دست آوردن مدل رگرسیونی مناسب، به‌کار گرفته شده است. واپنیک، برای اولین بار در سال ۱۹۹۸، این روش را براساس تئوری بهینه‌یابی پیشنهاد داد [9]. روش SVM برای تقریب توابع عملکرد با افزایش تعداد داده‌های آموزشی، کارایی مناسبی از خود نشان نمی‌دهد لذا کارایی آن برای سازه‌هایی که دارای

متغیرهای زیادی هستند، کمتر می‌شود و هزینه زمانی زیادی را برای آموزش مدل صرف می‌کند. برای رفع مشکلات ناشی از این روش، بای گانچن در سال ۲۰۰۹ به بررسی کاربردهای روش رگرسیونی کوچک‌ترین مربعات دستگاه بردارهای پشتیبان (Least Squares Support Vector Machine (LSSVM) و ترکیب آن با روش نمونه‌برداری مونت کارلوی معمولی پرداخت و با ارائه مثال‌های عددی نشان داد که این روش درمقایسه با روش SVM از کارایی بالاتری از لحاظ کاهش هزینه زمانی برخوردار است [10].

باتوجه به‌اینکه کاربرد روش LSSVM اخیراً به‌عنوان نسخه بهبودیافته‌ای از SVM در سایر رشته‌های علوم و مهندسی بسیار مورد توجه قرار گرفته است [10-13]، در تعیین قابلیت اعتماد سازه‌ها بسیار محدود است و هم‌چنین باتوجه به مشکلات روش‌های نوین دیگر برای کاهش زمان محاسبات؛ لذا در این مقاله از این روش استفاده شده است. زمان ناشی از تعداد تحلیل براساس روش شبیه‌سازی مونت کارلوی معمولی زیاد می‌باشد لذا در این مقاله بااستفاده از روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی و براساس اطلاعات اضافی مسئله، نواحی انتخابی نمونه‌ها در قسمت‌های مهم و موثر فضای متغیرها محدود شده و بدین ترتیب تعداد تحلیل‌های مورد نیاز و در نتیجه زمان کل محاسبات نسبت به روش شبیه‌سازی مونت کارلوی معمولی کاهش داده می‌شود.

در ادامه باتوجه به اصولی که هر کدام از روش‌های پیشنهادی در کاهش زمان محاسبات دارند، به بررسی روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی در جهت تولید نمونه‌ها برای تحلیل سازه‌ها و سپس به فرمول‌بندی LSSVM پرداخته می‌شود. در نهایت با ارائه نمونه‌هایی از سازه‌های اسکلتی (دو قاب و یک خرپا)، کارایی بالای الگوریتم‌های پیشنهادی درمقایسه با سایر روش‌های نوین ارائه‌شده در سالیان اخیر جهت تحلیل قابلیت اعتماد این سازه‌ها نشان داده شده

است.

خرابی واقعند برابر ۱ و در غیر این صورت برابر صفر در نظر گرفته می شود. تابع  $h_v(v)$  نیز به عنوان تابع چگالی بااهمیت مناسب می باشد. یک تخمین نارایب از احتمال خرابی به صورت رابطه (۴) بیان می شود.

$$p_f = \frac{1}{N} \sum_{j=1}^N (I(V_j) \frac{f_x(V_j)}{h_v(V_j)}) \quad (4)$$

در رابطه (۴) نمونه تصادفی  $V_i$  با استفاده از تابع توزیع بااهمیت  $h_v(v)$  تولید شده و  $f_x(v)$  نیز تابع توزیع احتمال اصلی متغیرها است [15].

#### روش نمونه برداری ابرمکعب لاتینی [16] (Latin Hypercube Sampling (LHS))

روش نمونه برداری ابرمکعب لاتینی برای اولین بار توسط «مکی» در سال ۱۹۷۹ ارائه شد [16]. این روش براساس روش لایه لایه شده (The Layered Method) به تقسیم محدوده تغییرات هر متغیر به صورت احتمال مساوی می پردازد. بدین ترتیب فضای متغیرها عملاً به صورت ابرمکعب هایی تقسیم می شود. سپس نمونه گیری از محدوده هر یک از این ابرمکعب ها به عمل می آید و براساس قضیه احتمال کل،  $P_f$  به دست می آید. در این روش تعدادی از مقادیر ممکن هر متغیر که به لایه هایی جزء بندی شده است، انتخاب می شود و یک مقدار از هر لایه به طور تصادفی به عنوان مقدار نماینده انتخاب می گردد. تابع حالت حدی  $Y$  با  $K$  متغیر تصادفی به صورت رابطه (۵) می باشد.

$$Y = f(x_1, x_2, \dots, x_k) \quad (5)$$

برای به دست آوردن اولین ترکیب، از هر متغیر تصادفی  $K$ ، یک نماینده به طور تصادفی انتخاب می شود. برای به دست آوردن دومین ترکیب، یک نماینده به طور تصادفی از  $N-1$  مقدار باقی مانده هر متغیر تصادفی  $K$ ، انتخاب می شود و این مراحل تا به دست آوردن  $N$  ترکیب از متغیرهای تصادفی ادامه داده می شود و در نهایت  $N$  مقدار نماینده برای هر کدام از  $K$  متغیر تصادفی به دست می آید. در کل،  $N^K$  ترکیب محتمل از

#### روش نمونه برداری بااهمیت

##### (Importance Sampling Method (ISM))

روش نمونه گیری بااهمیت یکی از روش های پیشرفته مونت کارلو می باشد که برای تخمین میزان احتمال خرابی و هم چنین تعیین محدوده های خرابی، مورد استفاده قرار می گیرد. اگر ناحیه خرابی به دست آمده از تحلیل سازه ها  $D$  باشد، آن گاه در حالت کلی احتمال خرابی هر سازه براساس تحلیل قابلیت اعتماد در این ناحیه، براساس رابطه (۱) بیان می شود [14].

$$p_f = \int_D \dots \int f_x(x) dx \quad (1)$$

در رابطه (۱)،  $f_x(x)$  تابع چگالی احتمال مشترک متغیرها،  $D$  ناحیه خرابی معین شده به وسیله یک یا چند تابع حالت حدی و  $P_f$  میزان احتمال خرابی سازه می باشد. با تعریف تابع نشانگر  $I(x)$  به گونه ای که به ازای نمونه های واقع در ناحیه خرابی  $I(x) = 1$  و در سایر موارد  $I(x) = 0$  باشد، می توان رابطه (۱) را برای همه متغیرها به صورت رابطه (۲) بیان نمود [۳].

$$p_f = \int_D \dots \int I(x) f_x(x) dx \quad (2)$$

برای تولید و شبیه سازی نمونه ها، به جای استفاده از تابع توزیع احتمالی اصلی متغیرها،  $f_x(x)$  از یک تابع چگالی احتمال جدید  $h_v(v)$  با عنوان تابع چگالی نمونه گیری بااهمیت استفاده می شود. بنابراین نتایج شبیه سازی باید به صورت توابع وزنی برای تخمین تابع چگالی بااهمیت، به کار گرفته شوند. با توجه به موارد ذکر شده، احتمال خرابی رابطه (۲) به صورت رابطه (۳) تصحیح می شود.

$$p_f = \int_D \dots \int \left\{ I(V) \frac{f_x(V)}{h_v(V)} \right\} h_v(V) dx \quad (3)$$

در رابطه (۳)، تابع  $I(V)$  به عنوان یک تابع نشانگر می باشد. مقدار این تابع برای نقاطی که در محدوده

نمونه اصلی تبدیل می‌کند.

$$f(x, w) = W \cdot \Phi(x) + b \quad (8)$$

بنابراین الگوریتم LSSVM قادر به تعیین تابع رگرسیون براساس یک مسئله بهینه‌سازی بر مبنای برنامه‌ریزی غیرخطی ( $\|w\|^2$ ) طبق رابطه (۹) و با قید تساوی (۱۰) می‌باشد.

$$\min j(w, e) = \frac{1}{2} w^T w + \gamma \sum_{i=1}^l e_i^2 \quad (9)$$

$$y_i = w^T \Phi(x_i) + b + e_i \quad (10)$$

$$i = 1, \dots, l$$

تابع لاگرانژ به صورت رابطه (۱۱) به دست می‌آید و با مشتق‌گیری از تابع لاگرانژ جمله‌ای قیود بهینه‌یابی نیز به صورت روابط (۱۲) به دست می‌آیند.

$$L(w, b, e, a) = j(w, e) - \sum_{i=1}^l a_i (w^T \Phi(x_i) + b + e_i - y_i) \quad (11)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow -\sum_{i=1}^l a_i = 0$$

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{i=1}^l a_i \Phi(x_i)$$

$$\frac{\partial L}{\partial e_i} = 0 \rightarrow a_i = \gamma e_i$$

$$\frac{\partial L}{\partial a_i} = 0 \rightarrow w^T \Phi(x_i) + b + e_i - y_i = 0$$

(۱۲)

روابط (۱۲) را برای سادگی می‌توان به صورت ماتریسی به شکل رابطه (۱۳) نمایش داد.

$$\begin{bmatrix} I & 0 & 0 & -Z^T \\ 0 & 0 & 0 & -I^T \\ 0 & 0 & \gamma I & -I \\ Z & 1 & I & 0 \end{bmatrix} \begin{bmatrix} w \\ b \\ e \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ y \end{bmatrix} \quad (13)$$

در رابطه ماتریسی (۱۳)، پارامترها براساس روابط (۱۴) به دست می‌آیند.

$$y = [y_1 \ y_2 \ \dots \ y_l]^T \quad (14)$$

این مقادیر می‌تواند وجود داشته باشد. هدف روش ابرمکعب لاتینی این است که با انتخاب  $N$  ترکیب از این مقادیر نماینده، یکی و تنها یک مقدار از  $N$  ترکیب را به دست آورد.

### فرمول‌بندی روش رگراسیونی کوچک‌ترین مربعات دستگاه بردارهای پشتیبان (LSSVM) [10-11]

تابع توزیع معین  $P(x, y)$  که در آن  $x \in R^n, y \in R$  را در نظر بگیرید، در نتیجه می‌توان نقاط نمونه‌برداری را براساس رابطه (۶) به صورت نگاشت نقاط در فضای  $R^d$  به  $R$  تولید نمود.

$$D: \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \subset R^d \times R \quad (6)$$

در رابطه (۱۱)،  $x_i$  بردارهای ورودی،  $y_i$  مقدار تابع حالت حدی،  $t = 1, 2, \dots, l$  ابعاد بردار و  $l$  تعداد مشاهدات ورودی‌ها و خروجی می‌باشد. می‌توان رابطه بین بردارهای ورودی  $x$  و خروجی  $y$  را به صورت  $y = f(x)$  در نظر گرفت. اگر رابطه خطی بین نقاط نمونه‌برداری، فرض شود، آن‌گاه تابع رگراسیونی به صورت  $f(x) = W^T(X) + b$  به دست می‌آید. در این تابع  $W$  و  $b$  به ترتیب بردار وزن و عرض مدل به دست آمده می‌باشد. خطای آموزشی تابع براساس کمترین ریسک به صورت رابطه (۷) به دست می‌آید.

$$\min j(w, e) = \frac{1}{2} w^T w + \gamma \sum_{i=1}^l e_i^2 \quad (7)$$

در رابطه (۷)،  $\square > 0$  و تابع  $f$  براساس روابطی که در ادامه ذکر می‌شود به دست می‌آید؛ اما در اغلب موارد، ارتباط غیرخطی بین بردارهای ورودی و خروجی برقرار می‌باشد. در نتیجه تابع رگراسیونی براساس تابع غیرخطی  $\Phi$  به فضایی با ابعاد بزرگ‌تر تبدیل می‌شود و در نتیجه رگرسیون خطی به رگراسیونی با ابعاد بالاتر تبدیل می‌شود. در نتیجه اگر بین نقاط نمونه‌برداری ورودی و خروجی رابطه غیرخطی (۸) فرض شود، آن‌گاه روش LSSVM به وسیله تابع غیرخطی  $\Phi$ ، تابع رگرسیون خطی را به یک تابع غیرخطی در فضای

برای ایجاد چنین مدلی، باید براساس میزان‌سازی بین مدل آموزش‌دیده و مقادیر تابع حالت حدی واقعی، تابع پاسخ مناسبی را به‌دست آورد، این در حالی است که مدل‌های دیگر باتوجه به عدم میزان‌سازی ممکن است توابع نامناسبی را به‌دست آورند. باتوجه به این‌که حل انتگرال مونت‌کارلوی معمولی رابطه (۲) در سازه‌های خرابی و قاب‌های فولادی که دارای توابع حالت حدی با متغیرهای زیادی هستند، نیاز به زمان بسیار زیادی خواهد داشت. بنابراین برای تسهیل در انتگرال‌گیری، از روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی استفاده شده است. با توجه به این‌که واریانس مقدار  $P_f$  با  $\sigma_{I(x)}^2$  (واریانس متغیرها) رابطه مستقیم و با تعداد نمونه‌های تولیدشده رابطه عکس دارد در نتیجه انحراف معیار مقدار  $P_f$  و حاصل تخمین مونت‌کارلو با نسبت  $N^{\frac{1}{2}}$  کاهش می‌یابد و این حکایت از همگرایی کند روش مونت‌کارلو دارد. همگرایی کند روش مونت‌کارلو با روش‌های ISM و LHS که بر مبنای کاهش واریانس هستند جبران خواهد شد. باتوجه به این‌که روش نمونه‌برداری بااهمیت برای افزایش تعداد نقاط نمونه‌گیری در ناحیه خرابی، از یک تابع چگالی احتمال که تأکید آن بر روی ناحیه خرابی است، استفاده می‌نماید، روش مناسبی برای نمونه‌برداری داده‌ها می‌باشد. برای انجام نمونه‌گیری و پخش نمونه‌ها در قسمت‌های مختلف خرابی، به شناسایی قسمت‌هایی که چگالی احتمال در آنها بزرگ است، اقدام می‌شود. روش نمونه‌برداری ابرمکعب لاتینی نیز برای تحلیل قابلیت اعتماد سازه‌های پیچیده‌ای که زمان محاسبه فقط یک نمونه شبیه‌سازی آن ممکن است بسیار زیاد باشد، به‌منظور کاهش تعداد نمونه‌های مورد نیاز مناسب است. باتوجه به مطالب ارائه‌شده، براساس روش‌های پیشرفته مونت‌کارلو تعداد تحلیل سازه نسبت به روش مونت‌کارلوی معمولی به‌طور قابل‌توجهی کاهش می‌یابد اما هم‌چنان تحلیل المان محدود امری ضروری می‌باشد. همان‌طور که در قسمت‌های قبل ذکر شد، روش‌هایی از

$$Z = [\Phi(x_1) \quad \Phi(x_2) \quad \dots \quad \Phi(x_l)]^T$$

$$e = [e_1 \quad e_2 \quad \dots \quad e_l]^T$$

$$a = [a_1 \quad a_2 \quad \dots \quad a_l]^T$$

$$1 = [1 \quad 1 \quad \dots \quad 1]^T$$

باتوجه به این‌که در مسائل بهینه‌یابی محاسبه ضرب داخلی  $\Phi(x_i)\Phi(x_j)$  مشکل می‌باشد، بنابراین به‌منظور تسهیل در محاسبات می‌توان تابع کرنل  $\Psi(x_i, x_j)$  را در روابط (۱۴) به‌جای ضرب داخلی نمود.

$$\Omega_{kj} = (\Phi(x_i))^T \Phi(x_j) = \Psi(x_i, x_j) \quad (15)$$

$$(k, j=1, 2, \dots, l)$$

برای تعیین پارامترهای تابع رگرسیون انتخابی a) و b) می‌توان با حذف e و w در رابطه (۱۴) و با استفاده از رابطه (۱۵)، رابطه (۱۶) را به‌دست آورد.

$$\begin{bmatrix} 0 & 1^T \\ 1 & \Omega + \gamma^{-1}I \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (16)$$

در رابطه (۱۶) بافرض  $A = \Omega + \gamma^{-1}I$  و باتوجه به معین بودن ماتریس فرض‌شده، می‌توان پارامترهای تابع رگرسیونی را براساس روابط (۱۷) به‌دست آورد.

$$a = A^{-1}(y - b1) \quad (17)$$

$$b = \frac{1^T A^{-1} y}{1^T A^{-1} 1}$$

بااستفاده از اولین رابطه از روابط (۱۲) و جایگزینی آن با رابطه (۱۵)، تابع رگرسیونی انتخابی به‌صورت رابطه (۱۸) به‌دست می‌آید.


$$f(x) = \sum_{i=1}^l a_i \Psi(x, x_i) + b \quad (18)$$

**الگوریتم‌های پیشنهادی براساس ترکیب LSSVM با روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی (LSSVM-ISM, LSSVM-LHS)**

ایده روش‌های پیشنهادی، به‌دست آوردن مدلی کارا و مناسب برای توصیف مجموعه داده‌های آموزشی و تخمین دقت مناسب برای داده‌های آزمایشی می‌باشد.

تحلیل قابلیت اعتماد سه سازه با توابع حالت حدی و تعداد متغیرهای مختلف پرداخته و کارایی بالای الگوریتم‌های پیشنهادی نسبت به دیگر روش‌های نوین نشان داده می‌شود. تعداد داده‌های آزمایش برابر ۲۵ و تعداد تحلیل‌ها برابر ۵۰ در نظر گرفته شده است. نتایج نشان‌دهنده کارایی بالای روش‌های پیشنهادی نسبت به دیگر روش‌ها می‌باشد. به منظور تشکیل مدل کارا، برای هر سازه، تحلیل حساسیت بر روی مجموعه داده‌های آموزشی انجام شده و مناسب‌ترین تعداد داده برای آموزش به دست آمده است.

**مثال ۱: قاب پرتال فولادی با ۳ دهانه و ۵ طبقه.**  
تحلیل این قاب برای اولین بار توسط آقایان بوچر و بورگاند ارائه شد [15]. شمای این قاب در شکل (۱) نشان داده شده است.



شکل ۱ شمای قاب پرتال خطی ۳ دهانه ۵ طبقه

این قاب پرتال شامل ۲۱ متغیر تصادفی می‌باشد. این متغیرها شامل مدول یانگ، ممان اینرسی، سطح مقطع اعضا با توزیع نرمال و هم‌چنین بارهای جانبی با تابع توزیع رایی می‌باشد. خصوصیات و پارامترهای آماری این متغیرها براساس جداول (۱) و (۲) می‌باشند. اگر جابه‌جایی مجاز این طبقه برابر با ۱۰ سانتی‌متر باشد، آن‌گاه معیار خرابی براساس تحلیل المان محدود به صورت تابع حالت حدی رابطه (۱۹) می‌باشد.

$$G(X) = 10 - U_x \quad (19)$$

قبیل شبکه عصبی بر پایه اصل مینیمم‌سازی ریسک تجربی و براساس توپولوژی مناسب تنها می‌توانند خطای آموزش را کاهش دهند و تعمیم‌دهنده کل داده‌ها نمی‌باشند و در نتیجه روش تحلیلی مناسبی برای پیش‌بینی رفتار سازه نمی‌باشند، این در حالی است که روش LSSVM بر پایه اصل مینیمم‌سازی ریسک سازه‌ای و بدون نیاز به توپولوژی با ایجاد مدلی مناسب و تعمیم آن به کل داده‌ها، روش تحلیلی مناسبی برای پیش‌بینی رفتار سازه ارائه می‌دهد و علاوه بر به دست آوردن خطای مناسب، زمان محاسبات را نیز به مقدار قابل توجهی کاهش خواهد داد.

در این مقاله الگوریتمی براساس ترکیب روش رگرسیون LSSVM با روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی ارائه شده است. اصول کلی این الگوریتم بدین صورت است که ابتدا مجموعه‌ای از داده‌ها که براساس روش‌های نمونه‌برداری بااهمیت و ابرمکعب لاتینی ایجاد شده‌اند، به دو گروه داده‌های آموزشی و آزمایشی تقسیم می‌شوند و پارامترهای مدل با استفاده از آموزش مجموعه داده‌های آموزشی (آموزش مدل LSSVM) و براساس توابع مختلف کرنل، به دست می‌آیند. براساس مدل آموزش یافته، تابع رگرسیونی جدیدی محاسبه می‌شود و در نهایت مقادیر تابع رگرسیونی به ازای داده‌های نمونه‌برداری شده محاسبه می‌شود و میزان احتمال خرابی تخمین زده می‌شود. الگوریتم‌های ترکیبی براساس اصولی که هر کدام از روش‌ها دارند، برتری‌های خاصی نسبت به تک‌تک آنها دارد. یکی از این مزیت‌ها، کاهش تعداد نمونه‌ها توسط روش‌های نمونه‌برداری پیشنهادی و کاهش تعداد تحلیل‌های المان محدود برای تعیین احتمال خرابی است که در صورت استفاده از مدل رگرسیونی LSSVM به صورت قابل توجهی کاهش می‌یابد. روش‌های نمونه‌برداری برای تعیین نمونه‌ها و مدل LSSVM برای تقریب محدوده خرابی به منظور تسهیل در انتگرال‌گیری عددی به کار می‌رود. در ادامه به بررسی

در رابطه (۱۹)،  $U_x$  جابه‌جایی افقی واقعی می‌باشد.

برحسب تابعی از متغیرهای تصادفی می‌باشد. نتایج به‌دست آمده براساس الگوریتم‌های پیشنهادی هم‌چنین نتایج روش‌های مراجع دیگر در جدول (۳) ارائه شده است (مقدار احتمال خرابی دقیق براساس روش شبیه‌سازی مونت‌کارلوی معمولی و با ۵۰۰۰۰۰ نمونه بعد از ۱۰ بار تحلیل پیاپی در زمان ۹۵۱۲ ثانیه برابر با ۰/۰۰۰۲۸۹ به‌دست آمده است). نتایج به‌دست آمده در جدول (۳) نشان‌دهنده کارایی بالای روش‌های پیشنهادی از لحاظ دقت محاسبات و کاهش هزینه محاسبات نسبت به دیگر روش‌های تحلیل این قاب

جدول ۱ خصوصیات اعضای قاب ۳ دهانه ۵ طبقه

سطح مقطع	ممان اینرسی	مدول یانگ	اعضا
A5	I5	E1	B1
A6	I6	E1	B2
A7	I7	E1	B3
A8	I8	E1	B4
A1	I1	E2	C1
A2	I2	E2	C2
A3	I3	E2	C3
A4	I4	E2	C4

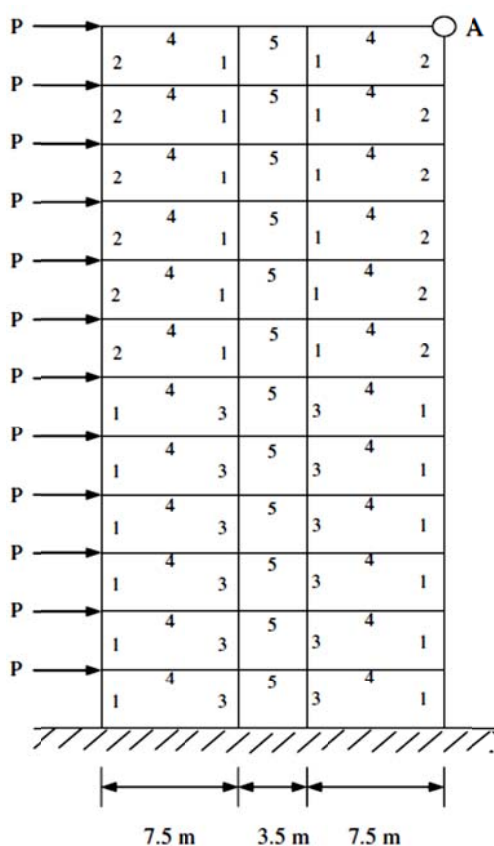
جدول ۲ پارامترهای آماری قاب ۳ دهانه ۵ طبقه

واحد	انحراف معیار	میانگین	تابع توزیع	متغیر تصادفی
KN	9	30	Rayleigh	P1
KN	8	20	Rayleigh	P2
KN	6.4	16	Rayleigh	P3
KN/m <sup>2</sup>	4000	45400	Normal	E1
KN/m <sup>2</sup>	4000	49700	Normal	E2
m <sup>4</sup>	13.72057	107.47	Normal	I1
m <sup>4</sup>	17.15071	152.06	Normal	I2
m <sup>4</sup>	34.3014	282.415	Normal	I3
m <sup>4</sup>	40.018	343.014	Normal	I4
m <sup>4</sup>	34.3014	142.92	Normal	I5
m <sup>4</sup>	45.7352	186.3711	Normal	I6
m <sup>4</sup>	74.319	307.569	Normal	I7
m <sup>4</sup>	85.753	343.014	Normal	I8
m <sup>2</sup>	6.4157	35.9281	Normal	A1
m <sup>2</sup>	8.5543	42.7716	Normal	A2
m <sup>2</sup>	10.692	58.1693	Normal	A3
m <sup>2</sup>	12.8314	64.1574	Normal	A4
m <sup>2</sup>	10.69	29.084	Normal	A5
m <sup>2</sup>	11.762	33.468	Normal	A6
m <sup>2</sup>	13.900	42.878	Normal	A7
m <sup>2</sup>	15.504	48.11805	Normal	A8

جدول ۳ نتایج روش‌های پیشنهادی و مرجع در مثال ۱

خطای نسبی (%)	زمان (ثانیه)	احتمال خرابی	تعداد داده آموزشی	تعداد نمونه	روش
0.34482	44.62	0.00029	150	500000	LSSVM-MCS
0.82361	24.67	0.000291	50	3000	LSSVM-ISM
1.027397	44.11	0.000292	200	3500	LSSVM-LHS
0.6872852	-	0.000291	-	-	FORM [8]
-31.36363	-	0.00022	-	-	KRIGING [8]
7.494838	-	0.000312	-	-	روش سطح پاسخ کلاسیک [8]

و برآورد احتمال خرابی را با دقت مناسب ارائه می‌دهند (مقدار احتمال خرابی دقیق با ۱۰۰۰۰۰ نمونه مونت‌کارلو و با ۱۰ بار تحلیل پیاپی در زمان ۵۲۴۶ ثانیه برابر با ۰/۰۷۵۱ به‌دست آمده است، این میزان برابر مقدار دقیق ارائه‌شده در مرجع ۷ می‌باشد).



شکل ۲ شمای قاب ۳ دهانه ۱۲ طبقه

جدول ۴ پارامترهای آماری قاب ۳ دهانه ۱۲

## مثال ۲: قاب پرتال فولادی با ۳ دهانه و ۱۲ طبقه.

قاب مفروض شامل یک قاب پرتال الاستیک خطی با ۳ دهانه و ۱۲ طبقه می‌باشد [7,13]. شکل (۲) این قاب را به‌همراه تیپ‌بندی تیر و ستون‌های آن نشان می‌دهد (ارتفاع هر طبقه ۴ متر می‌باشد). سطح مقطع تیر و ستون‌ها و همچنین بار افقی وارد به قاب به‌عنوان متغیرهای تصادفی مستقل در نظر گرفته شده‌اند. مدول یانگ به‌عنوان پارامتر قطعی برابر با  $2 \times 10^7$  می‌باشد. ممان اینرسی اعضای این قاب نیز به‌عنوان متغیری وابسته به سطح مقطع‌ها، براساس رابطه (۲۰) بیان می‌شود.

$$I_i = a_i A_i^2 \quad (20)$$


با فرض این‌که ماکزیمم جابه‌جایی افقی گره A برابر با ۰/۰۹۶ متر باشد، آن‌گاه تابع حالت حدی براساس پارامترهای تصادفی فرض شده، به‌صورت رابطه (۲۱) در نظر گرفته می‌شود.

$$G(x) = 0.096 - u_A(A_1, A_2, A_3, A_4, A_5, P) \quad (21)$$

پارامترهای آماری نمونه‌های تصادفی اصلی و ضرایب ممان اینرسی این قاب نیز مطابق جدول (۴) می‌باشد. نتایج به‌دست آمده از روش‌های پیشنهادی براساس تعداد نمونه‌های آموزشی که براساس تحلیل حساسیت به‌دست آمده‌اند، به‌همراه نتایج روش‌های پیشنهادی مرجع اصلی به‌صورت جدول (۵) می‌باشد. نتایج به‌دست آمده نشان می‌دهند که روش‌های پیشنهادی هزینه زمانی را به نحو مؤثری کاهش می‌دهند.



متغیرها، در جدول (۶)، ارائه شده است. هم چنین نتایج به دست آمده از روش های پیشنهادی براساس تعداد نمونه های آموزشی که براساس تحلیل حساسیت به دست آمده اند، به همراه نتایج روش پیشنهادی مرجع اصلی به صورت جدول (۷)، می باشد. میزان احتمال خرابی دقیق در مرجع ۳ برابر ۰/۰۱۴ به دست آمده است.



شکل ۳ هندسه خرابی ۱۵ عضوی

ضرایب $a_i$	توزیع	واحد	انحراف معیار	میانگین	متغیر
0.0833	Lognormal	m <sup>2</sup>	0.025	0.25	A <sub>1</sub>
0.0833	Lognormal	m <sup>2</sup>	0.016	0.16	A <sub>2</sub>
0.0833	Lognormal	m <sup>2</sup>	0.036	0.36	A <sub>3</sub>
0.2667	Lognormal	m <sup>2</sup>	0.02	0.2	A <sub>4</sub>
0.2	Lognormal	m <sup>2</sup>	0.015	0.15	A <sub>5</sub>
-	Type I Largest	KN	7.5	30	P

**مثال ۳: خرابی ۱۵ عضوی با تابع حالت حدی جابه جایی.** مثال آخر یک خرابی ۱۵ عضوی است که از مرجع ۳ برگرفته شده است. هندسه این خرپا در شکل (۳) نشان داده شده است. سطح مقطع همه ۱۵ عضو و ۳ بار متمرکز که بر گره های ۲، ۵ و ۶ وارد شده است، به عنوان متغیرهای تصادفی مستقل از هم می باشند. مدول یانگ نیز به عنوان پارامتر قطعی برابر با ۲۰۰ GPa فرض می شود. براساس تحلیل الاستیک خطی، میزان جابه جایی مجاز گره میانی (گره ۵) برابر با ۷/۵ سانتی متر به دست آمده است. پارامترهای آماری

جدول ۵ نتایج روش های پیشنهادی و مرجع در مثال ۲

خطای نسبی	زمان (ثانیه)	احتمال خرابی	تعداد داده	تعداد نمونه	روش
0.0665	17.09	0.07515	100	100000	LSSVM-MCS
0.0931	8.7	0.07517	60	1000	LSSVM-ISM
0.0665	5.75	0.07515	50	1000	LSSVM-LHS
-4.596	491.7	0.0718	-	-	GA-ANN [7]
3.346	80.7	0.0777	160	-	GA-ANN-MCSIS [7]
-1.417	-	0.07405	257	-	RBF-MCS [14]



جدول ۶ پارامترهای آماری خرابی ۱۵ عضوی

تابع توزیع	واحد	انحراف معیار	میانگین	متغیر
Normal	cm <sup>2</sup>	0.516	10.32	A1-A6
Normal	cm <sup>2</sup>	0.323	6.45	A7-A15
Lognormal	KN	0.09975	4.483	Ln P1
Lognormal	KN	0.09975	5.582	Ln P2
Lognormal	KN	0.09975	4.483	Ln P3

جدول ۷ نتایج روش های پیشنهادی در مثال ۳

خطای نسبی (%)	زمان (ثانیه)	احتمال خرابی	تعداد داده های آموزشی	تعداد نمونه‌ها	روش های پیشنهادی
-0.8645	15.36	0.001388	50	1000000	LSSVR-MCS
-0.3584	3.892	0.001395	50	3500	LSSVR-LHS
-0.7194	8.375	0.00139	60	1000	LSSVR-ISM

خطای نسبی مقادیر احتمال خرابی کاهش می‌یابد. باتوجه به این‌که مقادیر ضریب تغییرات و درصد خطای احتمال خرابی به‌دست آمده براساس تعداد ۵۰ و ۶۰ داده به‌ترتیب برای روش‌های LSSVM-LHS و LSSVM-ISM، در بازه مناسبی قرار دارد، درنتیجه می‌توان براساس تحلیل حساسیت داده‌های آموزشی، این تعداد را به‌عنوان تعداد داده‌های آموزشی مناسب درنظر گرفت.



شکل ۴ نمودارهای جذر میانگین خطای مربعات براساس تعداد داده‌های آموزشی مختلف

جدول ۸ تحلیل حساسیت بر روی داده‌های آموزشی و تعیین احتمال خرابی در روش LSSVM-LHS



**تحلیل حساسیت بر روی داده‌های آموزشی و تعیین میزان خطای داده‌های تست در مثال ۲.** تحلیل حساسیت بر روی مدل، براساس تعداد مختلفی از داده‌های آموزشی و با ثابت درنظر گرفتن تعداد داده‌های تست (تعداد داده‌های تست برابر با ۲۵ درنظر گرفته شده است)، انجام می‌شود. براساس این تحلیل حساسیت، محدوده مناسبی از داده‌های آموزشی به‌دست می‌آید. همان‌طور که در شکل (۴) قابل مشاهده است، در هر دو روش پیشنهادی LSSVM-LHS و LSSVM-ISM، میزان جذر میانگین خطای مربعات (RMSE)، ناشی از مقادیر تابع حالت حدی مدل ایجاد شده برای داده‌های تست، باافزایش تعداد داده‌های آموزشی، کاهش می‌یابد.

**تحلیل حساسیت بر روی داده‌های آموزشی و تعیین میزان احتمال خرابی در مثال ۲.** در این قسمت، تحلیل حساسیت برای یافتن بهترین مجموعه از داده‌های آموزشی، براساس میزان احتمال خرابی به‌دست آمده انجام شده است. این تحلیل بدین صورت است که در هرکدام از روش‌های پیشنهادی، با درنظر گرفتن تعداد مختلفی از داده‌های آموزشی، میزان احتمال خرابی سازه براساس ۱۰۰ بار تحلیل به‌دست می‌آید. نتایج به‌دست آمده در جداول (۸) و (۹) نشان داده شده است. شکل (۵) نیز مقادیر احتمال خرابی را برای تعداد داده‌های آموزشی مختلف برای هر دو روش نشان می‌دهد. مقدار ضریب تغییرات کمتر از ۰/۱ و درصد خطای کمتر از یک درصد به‌عنوان مقادیر مناسب درنظر گرفته می‌شوند. نتایج به‌دست آمده نشان می‌دهد که با افزایش تعداد داده‌های آموزشی، میزان ضریب تغییرات و درصد

زمان	خطای نسبی	ضریب تغییرات	انحراف معیار خرابی	احتمال خرابی	تعداد داده های آموزشی	تعداد نمونه	روش
1.45	8.414	0.93902	0.077	0.082	10	1000	LSSVR-LHS
2.05	3.717	0.355128	0.0277	0.078	20		
3.18	-0.805	0.21610	0.0161	0.0745	30		
4.42	0.3978	0.102122	0.0077	0.0754	40		
5.75	0.0665	0.035928	0.0027	0.07515	50		
7.15	0.0598	0.03526	0.00265	0.075145	60		
12.1	0.0266	0.019968	0.0015	0.07512	90		
14.95	0.0133	0.010065	0.000756	0.07511	100		
50.8	0.0066	0.006018	0.000452	0.075105	200		

جدول ۹ تحلیل حساسیت بر روی داده های آموزشی و تعیین احتمال خرابی در روش LSSVM-ISM

زمان	خطای نسبی	ضریب تغییرات	انحراف معیار خرابی	احتمال خرابی	تعداد داده های آموزشی	تعداد نمونه	روش
2.04	14.659	0.2867045	0.02523	0.088	10	1000	LSSVR-ISM
3.05	7.2839	0.2864197	0.0232	0.081	20		
4.076	4.936	0.2822784	0.0223	0.079	30		
6.23	3.717	0.2323076	0.01812	0.078	40		
7.51	1.830	0.1359477	0.0104	0.0765	50		
8.7	0.0931	0.098443	0.0074	0.07517	60		
12.05	0.05323	0.0598882	0.0045	0.07514	90		
15.74	0.0266	0.02808	0.00211	0.07512	100		
54.14	0.0106	0.0061	0.000463	0.075108	200		



شکل ۵ نمودارهای میزان احتمال خرابی براساس تعداد مختلفی از داده های آموزشی

در این مقاله به بررسی کارایی روش های LSSVR-LHS

## جمع بندی

قابلیت اعتماد نیاز به زمان زیادی جهت تحلیل المان محدود خواهند داشت. هزینه زمانی صرف شده از طریق روش‌های پیشنهادی به‌طور قابل توجهی از روش‌های دیگر کمتر می‌باشد. در ضمن، دقت محاسبات نیز در حد معقول و حتی بهتر از روش‌های دیگر خواهد بود.

و LSSVM-ISM پرداخته شد. براساس این روش‌ها و با استفاده از داده‌های آموزشی، مدل مربوط ایجاد شد و در نهایت براساس روش‌های پیشنهادی، میزان احتمال خرابی تخمین زده شد. با ارائه ۲ مثال از قاب و یک مثال خرابایی، نشان داده شد که روش‌های پیشنهادی جهت تقریب تابع رگرسیون، برای توابعی بسیار مفید هستند که دارای فرم ریاضی نیستند و جهت تحلیل

## مراجع

1. Nowak, A.S., Collins, K.R., "Reliability of Structures", *McGraw-Hill*, Boston, pp. 1-6, (2000).
2. Hurtado, J.E., "An Examination of Methods for Approximating Implicit Limit State Functions From the Viewpoint of Statistical Learning Theory", *Structural Safety*, Vol. 26, pp. 271-293, (2004).
3. Zhang, H., Robert, L., Muhanna, R., and Almgren, R., "Interval Monte Carlo Methods for Structural Reliability", *Structural Safety*, Vol. 32, pp. 183-190, (2010).
4. Rackwitz, R., "Response Surfaces in Structural Reliability", *Berichte Zur Zuverl Assign Keits Theorie der Bauwerke*, Heft 67 Munchen, (1982).
5. Deng, J., Gu, D., Li, X. and Yue, Z.Q., "Structural Reliability Analysis for Implicit Performance Functions Using Artificial Neural Network", *Structural Safety*, Vol. 27, pp. 25-48, (2005).
6. Gomes, H.M., Awruch, A.M., "Comparison of Response Surface and Neural Network With Other Methods for Structural Reliability Analysis", *Structural Safety*, Vol. 26, pp. 49-67, (2004).
7. Cheng, J., "Hybrid Genetic Algorithms for Structural Reliability Analysis", *Computers and Structures*, Vol. 85, pp. 1524-1533, (2007).
8. Kaymaz, I., "Application of Kriging Method to Structural Reliability Problems", *Structural Safety*, Vol. 27, pp. 133-151, (2005).
9. Vapnik V. "Statistical Learning Theory", John, Wiley and Sons., New York, (1998).
10. Zhiwei, G., Guangchen, B., "Application of Least Squares Support Vector Machine for Regression to Reliability Analysis", *Chinese Journal of Aeronautics*, Vol. 22, pp. 160-166, (2009).
11. Li, H.S. And Lu, Z.Z., "Support Vector Regression for Structural Reliability Analysis", *Applied Mathematics and Mechanics*, Vol. 27(10), pp. 1295-1303, (2006).
12. Zhao, W., Qiu, Z., "An efficient response surface method and its application to structural reliability and reliability-based optimization", *Finite Elements in Analysis and Design*, Vol. 67, pp. 34-42, (2013).
13. Deng, J. "Structural Reliability Analysis for Implicit Performance Function using Radial Basis Function Network", *International Journal of Solids and Structures*, Vol. 43, pp. 3255-3291 (2006).

14. Tang, C.X., Jin, W.L. and Chen, J., "Importance Sampling Method based on SVM", *J Yangtze River Scientific Res Inst*, Vol. 24(6), pp. 62–5, (2007).
15. Bucher, C.G., Bourgund, U., "A fast and Efficient Response Surface Approach for Structural Reliability Problems", *Structural Safety*, Vol. 7(1), pp. 57–66, (1990).
16. McKay, M.D., Beckman, R.J., "A comparison of Three Methods for Selecting Values of Input Variables in the Analysis of Output from a Computer Code", *Technometrics*, Vol. 42(1), pp. 239–45, (2000).

